

Česká zemědělská univerzita v Praze

Fakulta životního prostředí

Katedra prostorových věd



**Česká zemědělská  
univerzita v Praze**

Sledování vlivu krajinného pokryvu na kvalitu vody řeky Ohře pomocí metod dálkového  
průzkumu Země

Bakalářská práce

Vedoucí práce: Ing. David Moravec, Ph.D.

Bakalant: Ondřej Stehlík

**ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE**

Fakulta životního prostředí

# ZADÁNÍ BAKALÁŘSKÉ PRÁCE

Ondřej Stehlík

Geografické informační systémy a dálkový průzkum Země v životním prostředí

Název práce

**Sledování vlivu krajinného pokryvu na kvalitu vody řeky Ohře pomocí metod dálkového průzkumu Země**

Název anglicky

**Monitoring the influence of landscape cover on the water quality of the Ohře River using remote sensing methods**

---

## Cíle práce

Cílem práce je vyhodnotit, jaký dopad má typ krajinného pokryvu a jeho případná změna v čase na kvalitu vody v řece Ohři. Hodnocení kvality vody proběhne na základě metod dálkového průzkumu Země (DPZ).

## Metodika

V první části student provede rešerši problematiky hodnocení kvality vody pomocí metod DPZ. Dále pak proběhne rešerše současného stavu povodí řeky Ohře a kvality vody v ní.

V praktické části klasifikuje krajinný pokryv podél toku řeky Ohře v různých časových horizontech na snímcích družice Sentinel-2. Následně student vyhodnotí optické parametry metodou C2RCC popisující kvalitu vody na satelitních snímcích.

Porovnáním stavu krajiny v různých úsecích řeky a odpovídajícím parametrům kvality vody dojde k vyhodnocení vlivu krajiny na kvalitu vody řeky Ohře.

**Doporučený rozsah práce**

30 stran

**Klíčová slova**

Kvalita vody, Dálkový průzkum Země, Krajinný pokryv

---

**Doporučené zdroje informací**

- Brockmann, C., Doerffer, R., Peters, M., Kerstin, S., Embacher, S., & Ruescas, A. (2016, August). Evolution of the C2RCC neural network for Sentinel 2 and 3 for the retrieval of ocean colour products in normal and extreme optically complex waters. In Living Planet Symposium (Vol. 740, p. 54).
- Jiang, Dalin, et al. "Estimating the concentration of total suspended solids in inland and coastal waters from Sentinel-2 MSI: A semi-analytical approach." *ISPRS Journal of Photogrammetry and Remote Sensing* 204 (2023): 362-377.
- Llodrà-Llabrés, Joana, et al. "Retrieving water chlorophyll-a concentration in inland waters from Sentinel-2 imagery: Review of operability, performance and ways forward." *International Journal of Applied Earth Observation and Geoinformation* 125 (2023): 103605.
- Perrone, M., Scalici, M., Conti, L., Moravec, D., Kropáček, J., Sighicelli, M., ... & Malavasi, M. (2021). Water mixing conditions influence Sentinel-2 monitoring of chlorophyll content in monomictic lakes. *Remote Sensing*, 13(14), 2699.
- Sent, Giulia, et al. "Deriving water quality parameters using sentinel-2 imagery: A case study in the Sado Estuary, Portugal." *Remote sensing* 13.5 (2021): 1043.
- 

**Předběžný termín obhajoby**

2023/24 LS – FŽP

**Vedoucí práce**

Ing. David Moravec, Ph.D.

**Garantující pracoviště**

Katedra prostorových věd

Elektronicky schváleno dne 18. 3. 2024

**prof. Ing. Petra Šimová, Ph.D.**

Vedoucí katedry

Elektronicky schváleno dne 19. 3. 2024

**prof. RNDr. Michael Komárek, Ph.D.**

Děkan

V Praze dne 27. 03. 2024

## **Prohlášení**

Prohlašuji, že jsem bakalářskou/závěrečnou práci na téma:

Sledování vlivu krajinného pokryvu na kvalitu vody řeky Ohře pomocí metod dálkového průzkumu Země vypracoval samostatně a citoval jsem všechny informační

zdroje, které jsem v práci použil a které jsem rovněž uvedl na konci práce v seznamu použitých

informačních zdrojů.

Jsem si vědom, že na moji bakalářskou/závěrečnou práci se plně vztahuje zákon č. 121/2000

Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů,

ve znění pozdějších předpisů, především ustanovení § 35 odst. 3 tohoto zákona, tj. o užití tohoto

díla.

Jsem si vědom, že odevzdáním bakalářské/závěrečné práce souhlasím s jejím zveřejněním

podle zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů, ve znění

pozdějších předpisů, a to i bez ohledu na výsledek její obhajoby.

Svým podpisem rovněž prohlašuji, že elektronická verze práce je totožná s verzi tištěnou a že

s údaji uvedenými v práci bylo nakládáno v souvislosti s GDPR.

## **Poděkování**

Rád bych tímto poděkoval Ing. Davidovi Moravcovi Ph.D. za vytrvalé a odborné vedení při psaní této práce. Dále patří poděkování Ing. Petru Baštovi za konzultace ohledně dynamiky řek a vysvětlení, jakým způsobem vstupují látky do toků.

## **Abstrakt**

Tato bakalářská práce představuje komplexní analýzu vlivu krajinného pokryvu na kvalitu vody v povodí řeky Ohře, s využitím pokročilých metod dálkového průzkumu Země a geografických informačních systémů. Práce kombinuje využití satelitních snímků Sentinel-2 s geoprostorovým softwarem (ArcGIS Pro a SNAP) pro roky 2018 a 2020, čímž umožňuje podrobnou analýzu změn v krajinném pokryvu a jejich dopadu na vodní prostředí. V rámci studie byly vyhodnoceny spektrální indexy NDVI (Normalized Difference Vegetation Index) a BSI (Bare Soil Index), spolu s inherentními optickými vlastnostmi vody (IOPs), k detekci a kvantifikaci znečišťujících látek a biofyzikálních charakteristik vody. Tyto IOPs byly vyhodnoceny pomocí Case 2 Regional CoastColour (C2RCC), jenž je pokročilým hydrologickým nástrojem využívající metod deep learning neural networks. Analýza odhalila vztahy mezi krajinným pokryvem a kvalitou vody, zvláště v obdobích se zvýšeným znečištěním, což naznačuje potenciál dálkového průzkumu Země jako nástroje pro efektivní monitoring a management vodních zdrojů. Tato práce přispívá k lepšímu porozumění vlivu antropogenních a přírodních faktorů na kvalitu povrchových vod a poskytuje základ pro další výzkum v této oblasti.

**Klíčová slova:** Kvalita vody, Dálkový průzkum Země, Krajinný pokryv

## **Abstract**

This bachelor thesis presents a comprehensive analysis of the impact of land cover on water quality in the Ohře River basin, utilizing advanced methods of Earth remote sensing and geographic information systems. The study combines utilization of Sentinel-2 satellite imagery with geospatial software (ArcGIS Pro and SNAP) for the years 2018 and 2020, thereby enabling detailed analysis of changes in land cover and their impact on the aquatic environment. Within the study, spectral indices NDVI (Normalized Difference Vegetation Index) and BSI (Bare Soil Index) were evaluated, along with the inherent optical properties of water (IOPs), to detect and quantify pollutants and biophysical characteristics of water. These IOPs were evaluated using the Case 2 Regional CoastColour (C2RCC), which is an advanced hydrological tool utilizing deep learning neural networks methods. The analysis revealed relationships between land cover and water quality, especially during periods of increased pollution, indicating the potential of Earth remote sensing as a tool for effective monitoring and management of water resources. This work contributes to a better understanding of the impact of anthropogenic and natural factors on the quality of surface waters and provides a foundation for further research in this area.

**Key words:** Water quality, Earth remote sensing, Land cover

# Obsah

1	Úvod.....	1
2	Cíle práce.....	2
3	Literární rešerše .....	3
3.1	Kvalita povrchových vod na území ČR .....	3
3.2	Kvalita povrchových vod pomocí metod DPZ (doplnit zdroje) .....	3
3.3	Mise Sentinel-2 .....	3
3.3.1	Charakteristika senzorů .....	4
3.3.2	Možnosti využití Sentinel-2 v monitoringu kvality vod .....	5
3.3.3	Case 1 a Case 2 vody.....	5
3.4	Chlorofyl – a .....	5
3.5	Atmosférické korekce .....	5
3.6	Neuronové sítě.....	6
3.6.1	C2RCC .....	6
3.7	Metody klasifikace krajinného pokryvu .....	7
3.7.1	Bare Soil Index (BSI) .....	8
3.7.2	Normalized difference vegetation index (NDVI).....	8
3.8	Stav řeky Ohře rok 2018.....	9
3.9	Stav řeky Ohře rok 2020.....	10
3.10	Kvalita povrchových vod ve vztahu LULC .....	11
3.10.1	Problematika obalových zón.....	11
4	Metodika .....	12
4.1	Stažení snímků Sentinel-2 .....	12
4.2	Preprocessing.....	12
4.3	C2RCC procesor.....	14
4.4	Spektrální indexy.....	14
4.5	Vytvoření zón řeky .....	14
4.6	Extrakce hodnot IOP a spektrálních indexů .....	15
4.7	Vyhodnocení IOP vs index.....	15
4.8	Vyhodnocení trendů IOP v průběhu roku.....	15
5	Charakteristika studijního území .....	16
5.1	Karlovarský kraj.....	16
5.1.1	Lesy.....	16
5.1.2	Zemědělství .....	16
5.1.3	Vodstvo.....	17
5.2	Ústecký kraj.....	17



5.2.1	Lesy.....	18
5.2.2	Zemědělství .....	18
5.2.3	Vodstvo.....	18
6	Výsledky .....	19
6.1	Trendy IOP.....	19
6.2	Zhodnocení IOP v závislosti na NDVI a BSI .....	20
6.3	NDVI.....	20
6.4	BSI .....	22
6.5	Kros-korelace .....	22
7	Diskuse .....	23
8	Závěr a přínos práce .....	24
9	Přehled literatury a použitých zdrojů .....	25
10	Přílohy .....	29

## 1 Úvod

Voda je jedním ze základních podmínek pro život lidí, flóry i fauny na Zemi. Současné klimatické změny způsobující nárůst teplot mají výrazný vliv na naše životní prostředí, což se projevuje častějším výskytem období sucha a následnou erozí půdy. Tyto jevy mají negativní dopad na kvalitu vodních zdrojů. Kromě toho je kvalita povrchových vod zhoršována přítomností lidských sídel, průmyslovou činností a nezodpovědným způsobem obhospodařování krajiny, zejména díky intenzivnímu zemědělství (Kvítek, 2015).

Na území České republiky řeší ochranu vod zákon č. 254/2001 Sb., o vodách a o změně některých zákonů (vodní zákon), ve znění pozdějších předpisů. Problematika kontroly kvality povrchových vod spočívá v manuálním odběru vzorků, nákladné laboratorní analýze a bodovém měření, které bývá pouze několikrát do roka. Všechny tyto úkony jsou časově i finančně nákladné, a proto se jeví využití DPZ jako vhodná, levnější a rychlejší alternativa. Avšak metody DPZ neumožňují vyhodnotit veškeré parametry s tak vysokou přesností, které jsou vyhodnocovány v laboratořích (Brom et al., 2022).

V této práci se budu zabývat využitím možností a dat DPZ k odhalení vztahů mezi vlastnostmi krajinného pokryvu a kvalitou povrchových vod. Povrchové vody reprezentují především řeky, rybníky a vodní nádrže. Každý tento typ povrchové vody má ovšem svůj vlastní charakteristický ekosystém, a proto není možné porovnávat tyto typy mezi sebou. Kvůli tomu jsem se rozhodl pouze pro jeden typ a tím jsou řeky. Řeky jsem si vybral také proto, že nejsou ovlivněny zakrmováním, jako to je u rybníků určených pro chov ryb.

## **2 Cíle práce**

Cílem práce je vyhodnotit, jaký dopad má typ krajinného pokryvu a jeho případná změna v čase na kvalitu vody v řece Ohři. Hodnocení kvality vody proběhne na základě metod dálkového průzkumu Země (DPZ).

V první části bude provedena rešerše problematiky hodnocení kvality vody pomocí metod DPZ. Dále pak proběhne rešerše současného stavu povodí řeky Ohře a kvality vody v ní.

V praktické části bude klasifikován krajinný pokryv podél toku řeky Ohře v různých časových horizontech na snímcích družice Sentinel-2. Následně budou vyhodnoceny metodou C2RCC optické parametry popisující kvalitu vody na satelitních snímcích.

Porovnáním stavu krajiny v různých úsecích řeky a odpovídajícím parametrům kvality vody dojde k vyhodnocení vlivu krajiny na kvalitu vody řeky Ohře.

### **3 Literární rešerše**

#### **3.1 Kvalita povrchových vod na území ČR**

Pokud hovoříme o kvalitě vody, obecně tím rozumíme soubor fyzikálních, chemických či biologických vlastností, které řadíme do různých tříd závažnosti s ohledem na využití či použití vody. Využitelnost vody se liší od míry jejího znečištění, respektive toxicity, neboť každý organismus má jinou míru ekologické valence (Tůma et Kacálková, 2004).

Existují primárně dva přístupy ke zhodnocení kvality vody v ČR. Prvním je přímé měření, které řeší fyzikálně-chemické vlastnosti. Pokud budeme vycházet dle normy ČSN 75 7221 – klasifikace kvality povrchových vod, do chemických vlastností řadíme například koncentrace amoniakálního dusíku, celkového fosforu či rozpuštěný kyslík, které jsou udávány buď v mg/l nebo µg/l. Z fyzikálních vlastností to je poté elektrolytická konduktivita, která je udávána v mS/m. Druhý přístup ke zhodnocení kvality vody je na základě nepřímého měření, tzn. sledováním bioindikátorů, které nám udávají pravděpodobný stav vody.

#### **3.2 Kvalita povrchových vod pomocí metod DPZ (doplnit zdroje)**

Vyhodnocování indikátorů kvality povrchových vod zahrnující fyzikální, chemické a biologické vlastnosti je tradičně děláno odebráním in situ vzorků a následně podrobeno laboratorní analýze. Tento přístup je časově i finančně velmi náročný. I když laboratorní analýza má velkou přesnost, dochází pouze k bodovému zhodnocení. Kvůli výše zmíněným omezením se jeví využití metod DPZ jako časově i finančně úsporné. Na rozdíl od bodových vzorků, vyhodnocení satelitních snímků lze uskutečnit pro rozsáhlá území s pokrytím celých vodních útvarů (Arias-Rodriguez et al. 2021). Sledování kvality vod pomocí DPZ trvá již od roku 1972, kdy byl zahájen projekt družice Landsat-1 (NASA 1975). Většina studií se zaměřuje na monitoring metrik jako je chlorofyl-a (chl-a), celkové suspendované pevné látky (TSS) a zákal. Existují ovšem další proměnné jako je pH, celkový dusík (TN), amoniakový dusík (NH<sub>3</sub>-N), dusičnanový dusík (NO<sub>3</sub>-N) a rozpuštěný fosfor, které stávající literatura opomíjí. Hlavním důvodem jsou jejich slabé optické vlastnosti (Gholizadeh, 2016).

#### **3.3 Mise Sentinel-2**

Sentinel-2 je mise programu Copernicus, který je financovaný a řízený Evropskou unií ve spolupráci s ESA (European Space Agency). Tato mise se skládá ze dvou multispektrálních družic Sentinel-2 A a Sentinel-2 B. Díky jejich rozložení na oběžné dráze prolétne každá družice nad stejným místem na Zemi jednou za 10 dní.

V kombinaci dvou družic získáváme data pro stejné místo jednou za 5 dní. Družice 2A byla vypuštěna 23. června 2015 a 2B 7. března 2017. Jejich plánovaná životnost je 7 let, přičemž dle potřeby mohou sloužit až 12 let. Již nyní v roce 2024 se připravují družice 2C a 2D, které nahradí 2A a 2B, aby mise Sentinel-2 mohla dále kontinuálně probíhat (Majer, 2021).

### 3.3.1 Charakteristika senzorů

Družice disponují optickými senzory MSI (MultiSpectral Instrument) měřící reflektanci zemského povrchu s celkem třinácti pásmy různých vlnových délek. Tabulka č. 1 názorně ukazuje střední vlnové délky pásma, v kterých je senzor schopný snímat, šířku pásma a jeho příslušné prostorové rozlišení. V prostorovém rozlišení deset metrů se nachází čtyři pásma, (B2), 560 nm (B3), 665 nm (B4), 842 nm (B8), při rozlišení dvacet metrů je to šest pásem, (B5), 740 nm (B6), 783 nm (B7), 865 nm (B8a), 1610 nm (B11), 2 190 nm (B12) a v rozlišení šedesát metrů se nachází tři pásma 443 nm (B1), 945 nm (B9) and 1 375 nm (B10). Kromě výše zmíněných rozlišení je třeba také zmínit radiometrické rozlišení MSI. Radiometrické rozlišení udává nejmenší možnou zachycenou změnu intenzity a odrazu světla, jaký je senzor schopný odlišit. Radiometrické rozlišení MSI je 12 bitů, což umožňuje odlišit až 4095 různých hodnot (Copernicus, 2024).

Tabulka 1 specifikace pásem Sentinel-2, zdroj: Žubrietovský et al., 2017

Číslo pásma	Střední vlnová délka (nm)	Šířka pásma (nm)	Prostorové rozlišení (m)
1	443	20	60
2	490	65	10
3	560	35	10
4	665	30	10
5	705	15	20
6	740	15	20
7	783	20	20
8	842	115	10
8a	865	20	20
9	945	20	60
10	1380	30	60
11	1610	90	20
12	2190	180	20

### 3.3.2 Možnosti využití Sentinel-2 v monitoringu kvality vod

Pomocí snímků Sentinel-2 jsme schopni sledovat základní parametry kvality vod, jako je Chl-a, CDOM, TSM nebo zákal. Možnost jejich úspěšné detekce závisí na jejich optické aktivitě a spektrálních vlastnostech (Vinciková, 2015).

Sent (2021) ve své práci popisuje efektivitu a využití snímků Sentinel-2 pro odvození parametrů kvality vody v podobě CDOM, chlorofyl-a, PSM a turbidity. Jeho základní motivace byla ušetřit čas a prostředky při kontinuálním monitoringu parametrů kvality vody. Zkoumaná lokalita se nachází v Portugalsku a jedná se o přímořské ústí Sado. Ústí moří jsou z hlediska monitoringu výzvou, jelikož se zde míchá slaná i sladká voda. Nejpřesnější se prokázaly výsledky turbidity, ale pro ostatní parametry, především chlorofyl-a navrhuje další výzkum a nutnou implementaci lokálních parametrů prostředí do algoritmu.

### 3.3.3 Case 1 a Case 2 vody

Klasifikaci vod na „Case 1“ a „Case 2“ započal Morel and Prieur (1977). Jejich myšlenka rozdělovala vody na dva extrémní případy, kdy v ideální variantě má Case 1 dominantní zastoupení fytoplanktonu na úkor ostatních částic. Case 2 měl splňovat kritérium značného zastoupení anorganických částic. V obou případech je přítomná žlutá substance (Mobley et al., 2004). Žlutou substancí je myšlena největší komponenta rozpuštěné organické hmoty ve vodě. První definici žluté substance neboli „Gelbstoff“ popsal K. Kalle v roce 1966 (Davies-Colley, 1992).

## 3.4 Chlorofyl – a

Chlorofyl – a je pigment nezbytný pro fotosynteticky aktivní organismy ve vodě jako jsou zelené řasy a sinice, které jsou dominantní složkou fytoplanktonu. S přibývajícím koncentrací chlorofylu – a ve vodě roste také koncentrace těchto organismů, a proto jej lze považovat za spolehlivý indikátor specifického znečištění povrchových vod (Brom, 2022).

Metody DPZ nám umožňují detekovat různé látky na základě jejich spektrálních vlastností, respektive jejich schopnosti absorbovat a reflektovat určitou vlnovou délku elektromagnetického záření. Díky této vlastnosti jsme schopni odhadnout koncentrace chlorofylu – a ve vodách. Clarke a Ewing (1974) popsali vliv chlorofylu – a ve fytoplanktonu na odrazivost, která měla vrchol v 570 nm. Tento výzkum probíhal v Atlantickém oceánu. Další poznatky doplnil Hovis et al. (1980), který našel vrcholy absorpce v 443 a 670 nm.

## 3.5 Atmosférické korekce

Stěžejní proces pro co nejpřesnější vyhodnocení satelitních snímků je správná atmosférická korekce, protože data získaná pomocí satelitů obsahují nejen informace o odrazivosti povrchu vodních ploch, ale také o vlivu atmosféry, včetně rozptylu světla (např. Rayleighův rozptyl) a absorpce různými plynovými složkami atmosféry. Atmosférické korekce, které jsou vyvinuty pro oceány nebo pevninu mají často za

následek nízkou kvalitou odrazivosti pro použití na pobřežních či vnitrozemských vodách (Feng et al., 2018). Jiang (2023) Uvádí, že špatná atmosférická korekce může vést k nesprávné klasifikaci vody. Analýza vnitrozemských vod čelí specifickým problémům, které nejsou přítomné nebo jsou méně výrazné na plochách otevřených oceánů. Hlavním z nich je blízkost k pozemním zdrojům atmosférického znečištění způsobující heterogenitu atmosféry. Dalším důležitým faktorem je zvýšená koncentrace sedimentů pocházejících z prostředí zemědělské produkce, kde je značné riziko eroze a následných splachů pomocí dešťů. Tyto sedimenty způsobují zhoršenou odrazivost v oblasti blízkého infračerveného záření (Moses et al., 2017). Blízké infračervené pásmo je velmi důležité pro odstranění rozptylu způsobeného aerosoly, které výrazně přispívají do radiace zachycené senzorem. Možností korekce vlivu aerosolů je více, ale nejběžnějším je využití vlnových délek, ve kterých je voda vysoce absorpční a tím je právě NIR. Princip je takový, že radiance zachycená senzorem na těchto vlnových délkách je plně připisována příspěvku aerosolů, jelikož se očekává zanedbatelná radiance NIR z vodních ploch. Tento přístup poprvé využil Gordon a Clark z dat senzoru Coastal-Zone Color Scanner (CZCS) na satelitu Nimbus-7 (Moses et al., 2017). Této metodě se říká předpoklad černého pixelu a dá se využít pouze u čistých oceánských vod s minimální koncentrací pigmentů (Gordon et Clark, 1981). Pro lehce turbidní až extrémně turbidní vody se využívá kombinace pásem NIR a SWIR. Tato metoda je vhodná pro družice, které mají vysoké rozlišení a vysoké hodnoty signal to noise ratio (SNR) (Garg et al., 2017).

### **3.6 Neuronové sítě**

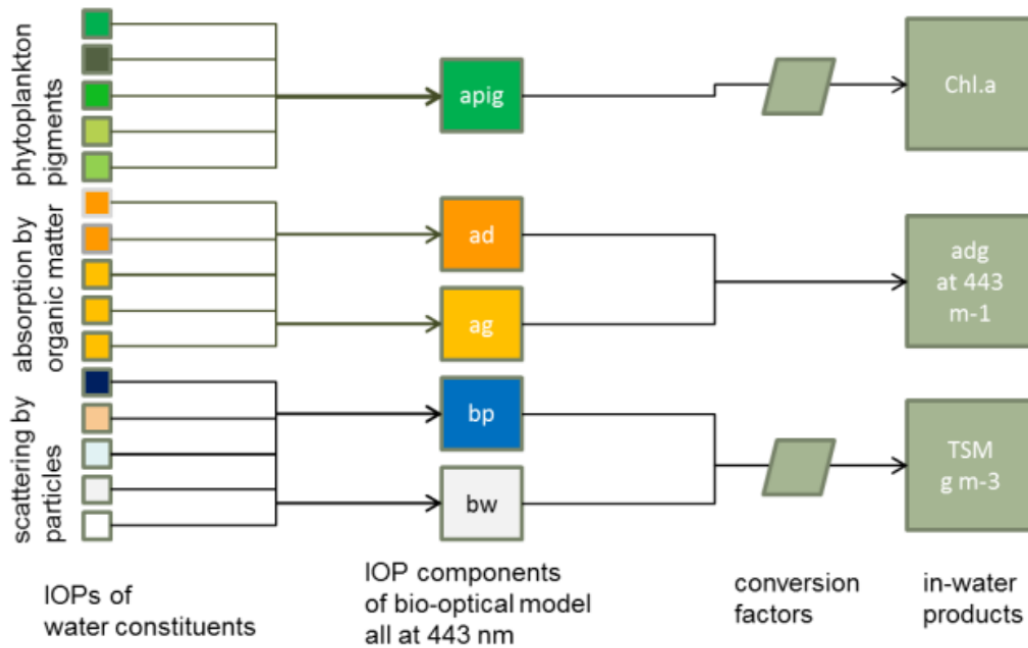
Neuronové sítě zastupují důležitou roli při metodách klasifikace krajinného pokryvu a monitorování biofyzikálních ekosystémových parametrů na základě dat DPZ (Kimes et al., 1999).

Jejich hlavní výhoda spočívá v jejich univerzálnosti, jelikož při standartní analýze je často nutností upravit parametry algoritmů na základě in situ měření pro specifickou oblast. Neurální sítě jsou natrénované na velkém množství dat, zpravidla pro různé typy vod a jiné geografické umístění (Lima et Marfurt, 2019). Využití metod strojového učení a hlubokého učení se ukázalo také být efektivnějším oproti lineárním a nelineárním modelům při stanovování chlorofylu – a. Především se projevila citlivost vyhodnocování dat ve vodách s nízkou hodnotou chlorofylu – a (Llodrà-Llabrés, 2023).

#### **3.6.1 C2RCC**

C2RCC je procesor pro aplikaci atmosférických korekcí a následného odvození složek či parametrů vody na základě satelitních snímků. Jeho algoritmické základy položili Schiller a Doerffer (1999). Tento algoritmus vyžaduje pro svůj vstup snímky TOA, které jsou následně pomocí neuronové sítě natrénované za účelem provádění inverze spektra pro atmosférickou korekci převedeny na BOA. Dokáže tak vypočítat záření, které se přímo odráží od vodních ploch bez vlivu atmosféry. Řádného vylepšení algoritmu bylo dosaženo díky projektu Coast Colour od ESA. Hlavní výhodou C2RCC je možnost využití pro vnitrozemské turbidní vody, tedy Case 2. Jeho funkce jsou přístupné v Sentinel toolbox, který je implementován do programu

SNAP. Výstupy po provedení AC jsou rastry v podobě hodnot inherentních optických vlastností vody (viz. Obr. 1). C2RCC rozlišuje primárně 5 rozdílných Parametr detekující pigmenty fytoplanktonu je `a_pig`. Organická hmota je charakterizována `a_det`, jako hodnoty absorpance detritu a `a_gelb` pro absorpaci gelbstoff (Brockmann, 2016).



Obrázek 1 Přehled IOPs v C2RCC, zdroj: Brockmann, 2016

Peronne (2021) zkoumala použitelnost C2RCC v kombinaci se snímky Sentinel-2 v monomiktických vulkanických jezerech. Pro přesnější výsledky algoritmu byly odebrány vzorky, na základě kterých byl vypočten exponent a faktor chlorofylu, který je třeba znát pro odhad koncentrace chlorofylu. Po provedení statistiky byla odhalena silná závislost mezi odhadovanou koncentrací chlorofylu pomocí C2RCC a in situ vzorky. Největší závislost se prokázala u fáze jezera, kdy se voda pomocí tepelné stratifikace míchala.

### 3.7 Metody klasifikace krajinného pokryvu

Při klasifikaci krajinného pokryvu pomocí dat DPZ je vždy třeba si uvědomit maximální možnou přesnost konkrétní metody a jaká má případná omezení. Existují primárně dvě metody klasifikace, a to řízená a neřízená. Principem neřízené klasifikace je shluková analýza, která na základě spektrálních vlastností rozřídí pixely do počtu požadovaných tříd. Tato metoda je pro zpracování poměrně jednoduchá, ale při vytvoření tříd vyžaduje následnou manuální kontrolu a pojmenování tříd. Použití řízené klasifikace vyžaduje v prvním kroku vytvoření trénovacích dat pro algoritmus. Pro výběr vhodných ploch k vytvoření trénovacích



dat je vhodné provést statistickou analýzu homogenity povrchu. Po označení a rozřazení trénovacích ploch do tříd nastává fáze zvolení vhodného klasifikátoru. Nejčastějšími typy jsou například klasifikátor nejbližšího souseda či maximální pravděpodobnosti. (Horák, 2014) Jelikož všechny tyto typy klasifikace vyžadují jistou dávku manuálního zásahu pro každý snímek nebylo by vhodné je využít pro potřeby této práce. Kromě časové náročnosti je otázkou jejich přesnost zařazení tříd. Peacock (2014) ve své práci popsal, že přesnost těchto klasifikací pro jeho zájmové území Little rocks v Arkansasu je od 67 % do 83 %.

### 3.7.1 Bare Soil Index (BSI)

Při klasifikaci krajinného pokryvu je značnou výzvou správně rozlišit holou půdu. Existuje více spektrálních indexů, které dokáží rozlišit holou půdu, ale jejich přesnost se odvíjí od vzoru krajiny a klimatických podmínek (Nguyen et al., 2021). Původní bare soil index (viz. Vzorec 1) byl vyvinut pro detekci půdní eroze v Jižní Africe. Jeho princip spočívá v použití vlnových délek středního infračerveného záření a viditelného zeleného záření. Kombinace těchto vlnových délek se ukázala jako účinná, protože dokázala holou půdu od vegetace rozlišit na základě vysokých a nízkých hodnot (Wentzel, 2002).

$$BSI = 100 \times \sqrt{\frac{TM7 - TM2}{TM7 + TM2}}$$

*Vzorec 1 Bare soil index (BSI)*

Protože původní BSI se v průběhu let ukázal jako málo přesný pro široké použití, vznikla celá řada jeho modifikací pro konkrétní potřeby a specifické lokality. Jedním z nich je Modified Bare Soil Index (viz. Vzorec 2), jenž se ukázal, že má přesnost až 98 %. Hodnoty vypočítaného indexu blízké se k 1 značí holou půdu a zastavěné oblasti (Nguyen et al., 2021).

$$MBI = \frac{SWIR1 - SWIR2 - NIR}{SWIR1 + SWIR2 + NIR} + f$$

*Vzorec 2 Modified Bare Soil index (MBI)*

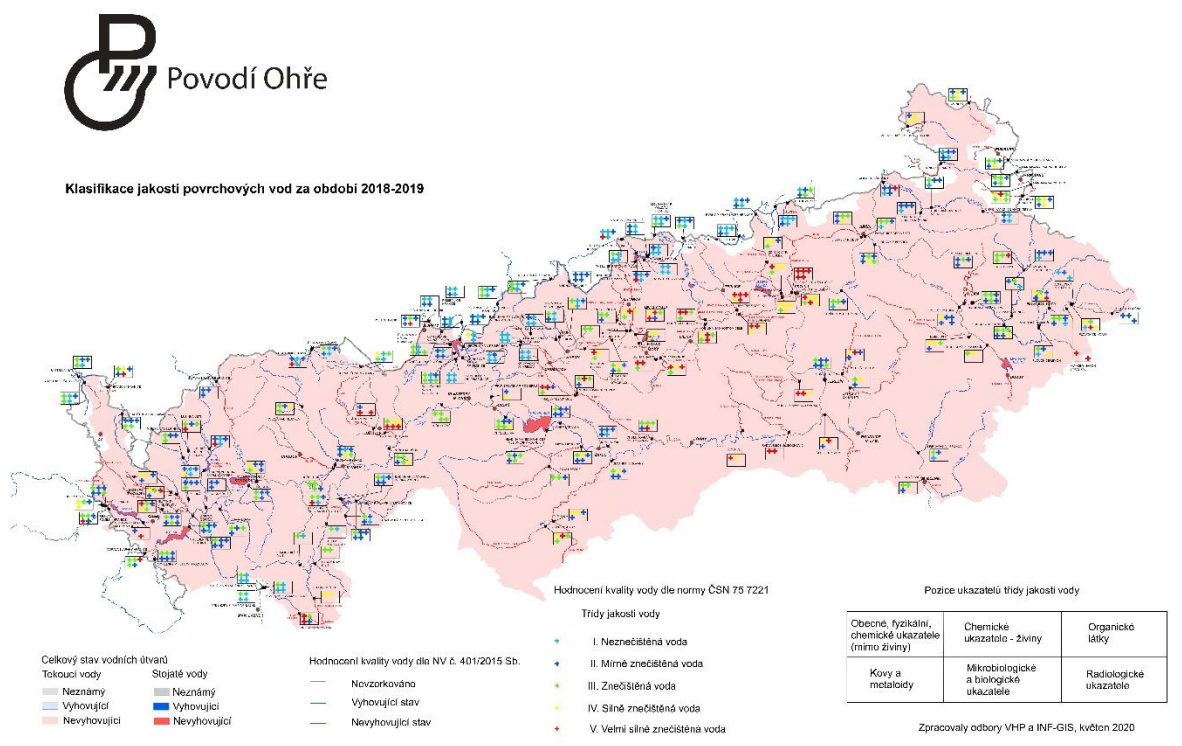
### 3.7.2 Normalized difference vegetation index (NDVI)

NDVI je spektrálních index, který využívá blízké infračervené záření a viditelné červené záření. Primárně se používá pro hodnocení zdravotního stavu vegetace. Zelené rostliny silně absorbují vlnové délky slunečního světla od 0.4 do 0.7  $\mu\text{m}$ , které využívají v procesu fotosyntézy. Naopak díky tomu, jak jsou buňky v listech uspořádány, odrážejí velké množství blízkého infračerveného záření. Pokud je více odraženého záření v NIR, než ve viditelném spektru, hodnotíme výsledek jako

hustou zdravou vegetací, která může charakterizovat les. Pokud je marginální rozdíl v podílu odraženého záření NIR a viditelného, je vegetace řídká a může se jednat o pastviny nebo nezdravou vegetaci. Hodnoty se pohybují od -1 do 1, přičemž 0 charakterizuje území bez listů (Weier et Herring, 2000).

### 3.8 Stav řeky Ohře rok 2018

Rok 2018 patřil k historicky průtokově podprůměrnému. Navazoval tak na období let 2014 až 2017, ve kterém se deficit srážek a sucho také projevovalo. Začátkem roku 2018 byly průtoky nadprůměrné díky rychlému tání sněhu, ovšem nedostatek srážek se začal projevovat během jara, a to mělo za následek v červenci podprůměrný stav průtoků u více než 80 % měrných profilů. Na mnoha tocích bylo nařízeno omezení odběru vody pro zachování ekologické funkce řeky. V tomto roce se velmi projevil význam nádrží a přehrad, které nadlepšovaly průtoky (POH, 2018). Na mapě níže (obr. 2) vidíme klasifikaci jakosti povrchových vod za období 2018-2019. Nevidíme zde trend znečištění v průběhu roku, ale zhodnocení celkové situace z pohledu různých typů znečištění.



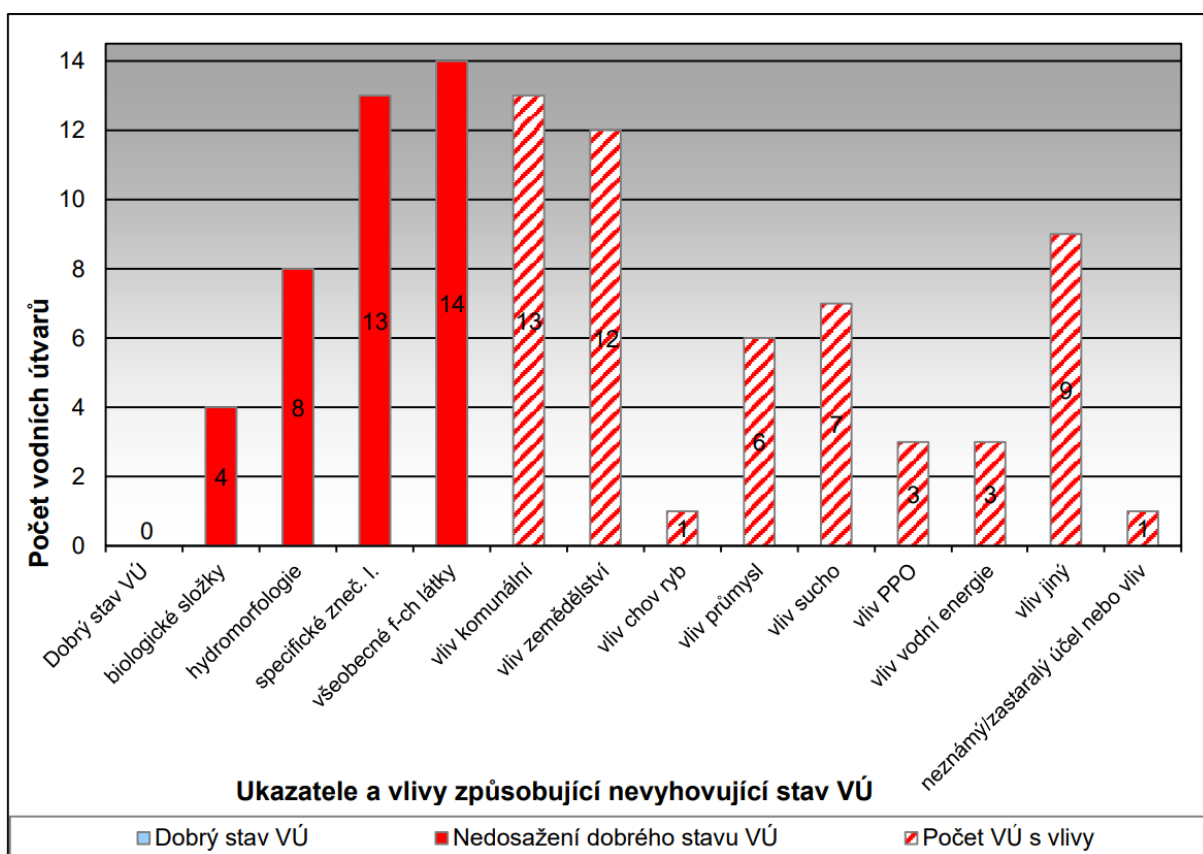
Obrázek 2 Mapa klasifikace jakosti povrchových vod za období 2018-2019, zdroj: POH, 2020

Veřejný přístup k datům ohledně kvality povrchové vody na Ohři je obtížný, pokud chceme zhodnotit historická data. Pro roky 2019 až 2022 existují dokumenty s názvem „hodnocení vývoje jakosti vod 2019-xx“, bohužel není možné se běžně dostat k datům měření parametrů jakosti, ze kterých tyto dokumenty vycházejí. Respektive, lze stáhnout z ISVS – VODA tabulku s omezenými parametry, které jsou chemického charakteru, nikoliv biologického. Dalším zdrojem informací může být web <https://sap.poh.cz/portal/jvn/cz/index.htm>. Lze jej použít pro poslední měření

chlorofylu na nádržích. Bohužel na portálu najdeme jen jednu hodnotu pro celou nádrž a odběry nejsou prováděné na všech nádržích ve stejný den, a proto můžeme tento údaj považovat spíše za orientační.

### 3.9 Stav řeky Ohře rok 2020

Rok 2020 byl opět jako rok 2018 zásadně ovlivněn suchem. Stalo se tak kvůli velmi malému množství sněhu, který by jinak zásobil řeku. Jakost vody lze hodnotit jako nevyhovující ve většině měrných profilech (viz. Graf 1). Dokument „Hodnocení vývoje jakosti vod 2020-2021“ hodnotí kvalitu vody v různých přítocích Ohře, i hlavním toku. Celkově lze říci, že velký podíl na znečištění mělo zemědělství v podobě zvýšených koncentrací dusík, fosforu a pesticidů. Bodový zdroj znečištění byla kontaminace odpadních vod. Vyskytla se zde i havárie, která způsobila zvýšený výskyt rtuti, který měl dopad na koncentrace rtuti v konzumovaných rybách (POH, 2020).



Graf 1 Ukazatele a vlivy způsobující nevyhovující stav VÚ, zdroj: POH, 2020

### 3.10 Kvalita povrchových vod ve vztahu LULC

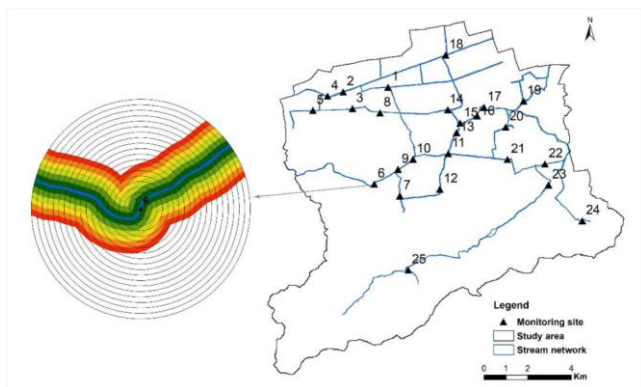
Změny ve využívání krajiny a typu krajinného pokryvu narůstají a mají negativní dopady na životní prostředí, především kvalitu vod (Mzuza et al., 2019). (Příčinou změny využití krajiny je urbanizace a s ní spojený populační růst. Kvůli těmto faktorům se přeměňují lesy na zastavěnou plochu a orné půdy (Dube et al., 2014). Potřeby pro nasycení lidí zvyšují nároky na zemědělce a ti v zájmu vyšších výnosů aplikují více hnojiv, což se projevuje v kvalitě orné půdy. V důsledku eroze se pak prvky z hnojiv, jako jsou především dusík a fosfor, dále dostávají do vod (Vitousek et al., 2009). To má za následek zhoršení kvality většiny sladkovodních vod, které jsou nezbytné pro zdraví lidí a produkci potravin (Ramadas et Samantaray, 2018). Vyplavený dusík a fosfor ze zemědělských ploch má také vliv na kvalitu podzemních vod. Mimo jiné, tento odliv látek způsobuje v řekách, jezerech a pobřežních částech zvýšenou eutrofizaci (Carstensen, 2020).

Goyenola et al. (2020) ve své práci zkoumal vliv intenzivního zemědělství z hlediska vstupů a výstupu dusíku v nížinných oblastech Uruguaye a Dánska. Byla prokázána závislost mezi vstupy dusíku do půdy a následnou zvýšenou koncentrací dusíku v povodí. Podotýká také ekosystém polí z hlediska významu drenáže. Pokud pole obsahují drenáže, nepřichází zde proces denitrifikace skrz podzemní vody, a tak se vyplavuje do řek přímo mnohem více dusíku než v oblastech bez drenáže.

Ta et al. (2020) prováděl analýzu současného stavu vod a vyhovujícího stavu vod dle norem EU, Water Framework Directive (WFD) na území Šlesvicko-Holštýnska. Výsledkem bylo odhalení překročení koncentrací fosforu ve vodách v 60 % na 6407 odebraných vzorcích. Uvedl, že většina emisí fosforu do řek je primárně ze zemědělských zdrojů.

#### 3.10.1 Problematika obalových zón

Pro sledování vlivu krajiny na kvalitu povrchových vod je třeba vymezit okolí vodního toku, u kterého je následně prováděno pozorování. Obalové zóny lze dělit na dva základní druhy. Pobřežní, které se nachází podél řeky zpravidla od 50 do 300 m (viz. Obr. 3). Druhým typem jsou kruhové zóny, které jsou v okolí 50 až 1000 m od bodu, kde byl odebrán vzorek. Třetí možnost pro vyhodnocení vlivu LULC na parametry vody je v rámci dílčího povodí. (Song et al., 2020)



Obrázek 3 Vizualizace obalových zón dle Song et al., 2020

Pohledy dalších studií se různí na ideální velikost bufferu podél řek. Uriarte (2011) zvolila pro analýzu vlivu typu krajiny na kvalitu vody obalovou zónu 60 m od řeky. Její model dokázal vysvětlit 30-58 % rozptylu metrik kvality vody. Na druhou stranu Wang (2023) testoval, jaký dopad má velikost různých obalových zón na vysvětlení množství znečištění v kontextu krajinného pokryvu. Jeho výsledky ukazují na malý vliv lesních porostů v malém měřítku zón a s rostoucí velikostí až do 1000 m se zvyšuje i dopad na kvalitu vody, který je v záporné korelaci. Tudiž, lesy mají pozitivní vliv na kvalitu vody. Ideální obalovou zónu stanovil na 1000 m. Vysvětluje také, že hodnota korelace krajinného pokryvu a metrik znečištění vody je proměnlivá v čase, a to především na základě ročních období, které jsou charakteristické svými průtoky.

## **4 Metodika**

### **4.1 Stažení snímků Sentinel-2**

Snímky Sentinel-2 v úrovních zpracování L1C a L2A byly staženy z Copernicus Data Space Ecosystem. Parametry pro vyhledávání bylo datum pořízení snímků ve vegetačním období od 1. dubna po 31. říjen v letech 2016 až 2023, dále maximální zastoupení mraků do 10 % a lokalizace v rámci zájmového území pomocí WKT. Pro získání WKT zájmového území bylo nutno exportovat povodí 1-13-02 Teplá a Ohře od Teplé po Liboc z dat databáze DIBAVOD. Tento krok byl proveden v programu QGIS. Jelikož data DIBAVOD jsou v souřadnicovém systému s kódem EPSG:5514, pro kompatibilitu se snímky Sentinel-2 bylo povodí převedeno do EPSG:4326. Pomocí QGIS pluginu GetWKT byly exportovány souřadnice povodí do WKT a nahrány do stahovací aplikace Copernicus Data Space Ecosystem.

Při vyhledávání se ukázalo, že ve vegetačním období s výše zmíněnými parametry existuje pouze pár snímků pro každý jeden rok. Následovala selekce, kdy bylo požadováno zastoupené rozložení alespoň 5 snímků do celého vegetačního období. Kvůli této komplikaci byly vyhovující pouze roky 2018 a 2020.


### **4.2 Preprocessing**

Vstupní data pro preprocessing byly snímky Sentinel 2 v levelu 1C a 2A. Cílem této části bylo připravit data v programu SNAP do podoby, aby se následně mohly využít v C2RCC procesoru (snímky L1C) a aplikování spektrálních indexů (snímky L2A). Jelikož se jedná o velké množství objemných dat, kdy jeden snímek má velikost od 600 MB do 1 GB, bylo nutností procesy automatizovat, s ohledem na výpočetní možnosti.

Pro potřeby automatizace byla prvně zvažována možnost využití SNAP Graph Processing Tool. Jedná se o nástroj příkazového řádku ze Sentinel toolboxu, který umožňuje na základě vytvořeného grafu processingu a použití funkcí, které se do grafu nedají zahrnout, automatizovat celý proces od preprocessingu po kompletní zpracování dat. Jeho výhodou je také možnost zahrnout vstupní parametry pro každý snímek definované ve vytvořených textových souborech. Inspirací pro vytvoření gpt skriptu byl RUS (Research and User Support) webinář s názvem „Freshwater Quality

Monitoring with Sentinel-2“. Tento postup se zdál být velmi užitečný, ovšem nebylo možné získat potřebné vstupní parametry pro každý snímek.

Proto bylo přistoupeno k časově náročnější možnosti, a to zpracovat jednotlivé snímky pouze s vytvořením grafu procesů (viz. Obr. 4).



Obrázek 4 Přehled procesů předzpracování v programu SNAP, zdroj: vlastní

Funkcí tohoto grafu je načtení snímku, import vektoru povodí, resampling všech pásem, použití subsetu pro oříznutí snímků, aplikace masky na základě vektorové vrstvy povodí a následný zápis dat.

Vstupní data byly použity, jak snímky L1C, tak L2A. Jako vektorová vrstva posloužila projektovaná vrstva z předchozího kroku. Pro zachování co nejlepšího prostorového rozlišení v resamplingu bylo použito referenční pásmo B2 s rozlišením 10 m/pixel. Provedení subsetu v následujícím kroku bylo především kvůli zmenšení dat a s tím související zkrácení výpočetní doby. Parametr subsetu vyžaduje rozsah zájmového území. K tomuto kroku byl odvozen rozsah povodí v QGIS a následně získané WKT bylo upraveno a použito jako parametr subsetu. Subset pásem nebyl nijak omezen. Vstupní parametr pro Land-Sea-Mask byla importovaná vrstva povodí. Zápis byl vždy nastaven do předem připravených složek, které byly hierarchicky rozřazeny dle roku a měsíce. Každé zpracování snímku dle vytvořeného grafu obsahovalo ručně nastavení vstupu, výstupu, a především znovunastavení pásma B2 v resamplingu, jelikož při načtení grafu se vždy zvolilo defaultně pásmo B1. Kontrola této chyby zamezila chybnému výslednému prostorovému rozlišení.

### 4.3 C2RCC procesor

Vstupní data pro C2RCC byly použity snímky L1C. Pro co nejpřesnější zpracování algoritmus vyžaduje zadání vstupních parametrů jako je salinita, ozon, teplota a atmosférický tlak (viz obr. 5). Díky nejnovější verzi SNAP 9.0.2. bylo možné tyto parametry kromě salinity pro každý snímek načíst z auxilárních dat. Pro tuto možnost bylo nastaveno v parametrech „Use ECMWF data, if available“. Jelikož zájmové území obsahuje pouze vnitrozemní vody, byla salinita nastavena na nejmenší možnou hodnotu, a to 0,0001 PSU.

Výsledkem zpracování C2RCC byly TOA reflektance, které zahrnují všech 5 typů IOP.

### 4.4 Spektrální indexy

Spektrální indexy byly vypočteny také v programu SNAP, ale na zpracovaných snímcích L2A. NDVI bylo použito v standartním nastavení. Výpočet BSI proběhl vytvořením band math s následujícím vzorcem.

$$BSI = ((SWIR2 + R) - (NIR + B)) / ((SWIR2 + R) + (NIR + B))$$

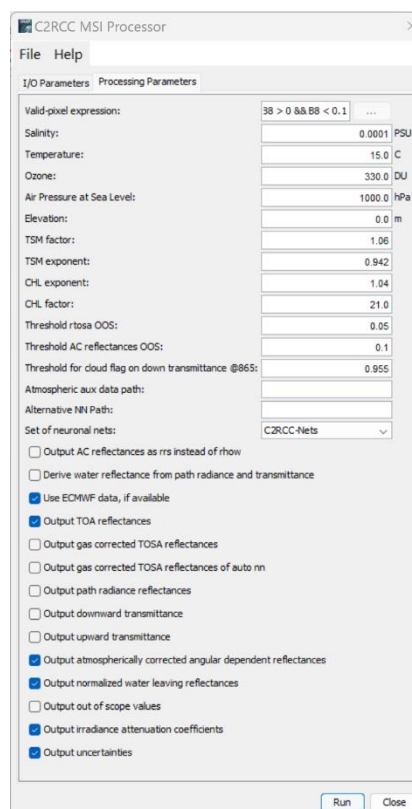
Pro použití na Sentinel-2 je kombinace pásem:

$$BSI = ((B11 + B04) - (B08 + B02)) / ((B11 + B04) + (B08 + B02))$$

### 4.5 Vytvoření zón řeky

Vytvoření zón řeky probíhalo v programu ArcGIS Pro 3.2.2. V první fázi zpracování byl vytvořen polygon řeky Ohře v rozsahu povodí. Z tohoto polygonu byly odstraněny vodní nádrže, jako jsou Nechranice. Tento krok byl nutný, jelikož vodní nádrže mají zcela odlišný tok látek, než řeky a nedává smysl je souběžně porovnávat. Následně byla vytvořena středová linie řeky. V další fázi nastalo rozhodnutí pro vzdálenost zón po řece a velikost obalové zóny řeky. Vzdálenost každé zóny byla určena 50 metry, aby bylo možné v analýze zhodnotit i menší projevy metrik kvality vody.

K rozdělení linie po 50 metrech bylo použito několik funkcí. První byla funkce „point features along a line“, která na linii vytvořila body po 50 metrech. Linie byla následně rozdělena pomocí funkce „split line at point“. Nyní byly vytvořeny kolmice v koncových bodech rozdělené linie pomocí „Generate Transects Along Lines“ o velikosti 120 m na levou i pravou stranu řeky. Tyto kolmice následně byly



Obrázek 5 Přehled nastavených parametrů v C2RCC, zdroj: vlatní

použity pro funkci „buffer“ v jednom směru. Díky tomu byly vytvořeny zóny řeky, které zatím obsahují i území kolem řeky. Vytvoření zvláště zón krajinného pokryvu a zvláště řeky bylo dosaženo použitím `intersect`, kde vstupní data byl polygon zvektorizované řeky a vytvořený buffer. Následně byly exportované zvláště zóny krajinného pokryvu a zóny řeky. Tímto postupem se docílilo zón krajinného pokryvu v průměrné vzdálenosti 80 m od řeky. Ačkoli na základě literární rešerše bylo zjištěno, že tato vzdálenost nedosahuje zpravidla významných odhalení rozptýlů LULC a metrik kvality vody, bylo stěžejní přistoupit na tuto velikost pro přesnější vyhodnocení na základě spektrálních indexů. V obou vrstvách byl následně vytvořen a vyplněn atribut NID, který identifikuje každou zónu.

#### **4.6 Extrakce hodnot IOP a spektrálních indexů**

Jednotlivé IOP byly načteny jako rastry z výsledků C2RCC. Pomocí zonální statistiky, kde zóny byly definovány jako shapefile zón řeky a vstupní data byly jednotlivé rastry IOP byly vytvořené atributové tabulky s průměry IOP v každé zóně. Stejný proces byl proveden i s rastry indexů BSI a NDVI, ale vrstva zón byl shapefile zón krajinného pokryvu. Všechny výsledné tabulky byly následně připojeny do vrstvy zón řeky na základě NID. Tímto bylo docíleno průměrných hodnot jednotlivých IOP a spektrálních indexů v jedné datové sadě.

#### **4.7 Vyhodnocení IOP vs index**

Statistické vyhodnocení probíhalo v programu R Studio za pomoci vytvořených skriptů pro hromadné zpracování.

Předpokladem ke správnému vyhodnocení byla eliminace nevhodných záznamů v atributové tabulce. Tyto záznamy obsahují prázdné řádky minimálně v jednom z atributových sloupců buď IOP nebo spektrálních indexů. Tato chyba vznikla, když C2RCC nebyl schopný v některých zónách klasifikovat vodu.

Vyčištění dat proběhlo pomocí funkce `na.omit()`. Následovala křížová korelace funkcí `ccf`. Díky tomuto kroku bylo odhaleno, že různé IOP mají svůj největší projev až v dalších zónách, a proto při následném kroku bylo nastaveno příslušné zpoždění pro každý IOP.

Pro každý IOP byla provedena spearmanova korelace s příslušným spektrálním indexem. Výsledné korelace byly exportovány do tabulky. Vizualizace vztahů IOP vůči spektrálním indexům byla provedena pomocí bodového grafu a regresní křivky.

#### **4.8 Vyhodnocení trendů IOP v průběhu roku**

Pro tento úkol byl použit program ArcGIS Pro. Po načtení všech snímků s IOP byla provedena zonální statistika pro celý shapefile řeky bez zón s parametrem průměru pro IOP. Následně byl pomocí datové analýzy vyhodnocen průměr jednotlivých IOP v celé řece. Tyto hodnoty byly zaznamenány do tabulek a následně vytvořeny grafy



pro rok 2018 a 2020. Na základě výsledných průměrů byla provedena korelační matice pro všechny IOP v daném roce.

## **5 Charakteristika studijního území**

Tato práce řeší zájmové území části povodí třetího řádu „Teplá a Ohře od Teplé po Liboc“, které zasahuje do Karlovarského, ale také Ústeckého kraje na území České republiky. Zvolené povodí se označuje kódem 1-13-02, který je stanoven dle vyhlášky ministerstva Zemědělství č. 393/2010 Sb., o oblastech povodí.

### **5.1 Karlovarský kraj**

Karlovarský kraj je příhraniční region na západě České republiky sousedící s Německem. Zaujímá rozlohu 3 314,4 km<sup>2</sup>, což tvoří 4,2 % celé rozlohy ČR. Jedná se tak o druhý nejmenší kraj, hned po kraji Libereckém. Z geomorfologického hlediska řadíme toto území do Krušnohorské provincie, která se dále člení na Krušnohorskou hornatinu, Podkrušnohorskou oblast a Karlovarskou vrchovinu. Nalezneme zde řadu přírodních zajímavostí, jako je například národní přírodní rezervace Soos se svým souborem vzácných slatinišť a oligotrofních jezírek, či CHKO Slavkovský les a jeho bučiny v údolích řek Teplá a Ohře (Karlovarský kraj, ©2024). Zastoupení krajinného pokryvu Karlovarského kraje lze vidět na grafu č. 2.

#### **5.1.1 Lesy**

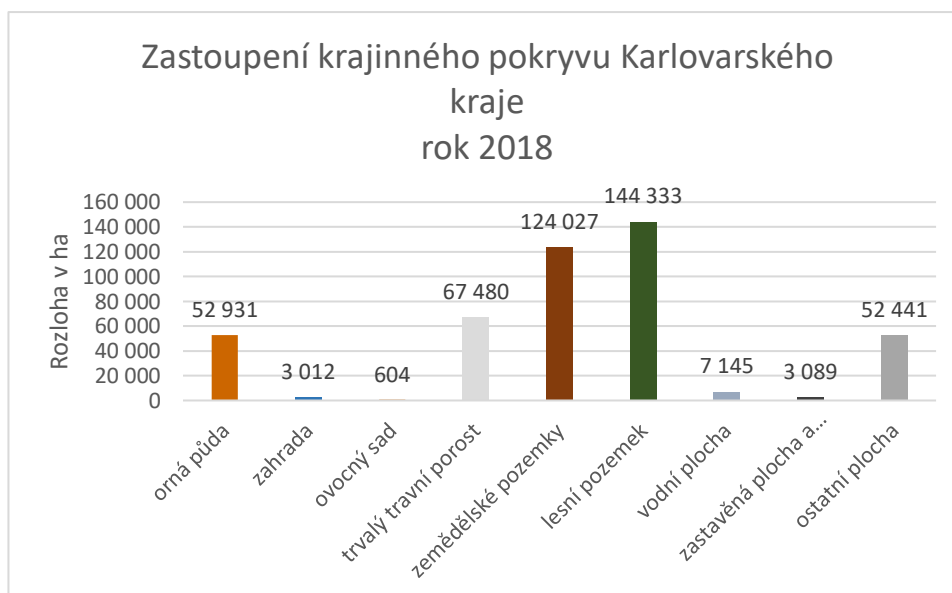
Z grafu (č.) je vidět, že největší podíl na krajinném pokryvu mají lesy. Lesnictví a zpracování dřeva patří k důležitým hospodářským odvětvím Karlovarského regionu. Z hlediska biodiverzity a ochrany půdy mají lesy neodmyslitelnou funkci, jelikož zabraňují erozi a slouží jako regulační prostředek vodních toků. V neposlední řadě přinášejí zdejší lesy i zóny relaxace pro turisty, kteří přijíždějí kvůli léčivým pramenům, jenž je na Karlovarsku mnoho (Karlovarský kraj ©2024).

#### **5.1.2 Zemědělství**

V oblasti zemědělství je ovšem unikátní hned v několika ohledech. Má nejmenší procentuální zastoupení orné půdy ze všech krajů a zároveň největší podíl ekologicky obhospodařované zemědělsky využívané půdy. Pěstují se zde především obilniny a píce ke krmným účelům. Zbytek zemědělské půdy je využíván k chově skotu, koz a ovcí (Karlovarský kraj, ©2024).

### 5.1.3 Vodstvo

Území Karlovarského kraje obsahuje dvě povodí třetího řádu, a to řeky Berounky a řeky Ohře. Největší význam má ovšem řeka Ohře, neboli německy Eger. Pramení v Horních Francích v Bavorsku a dále protéká od západu k východu Karlovarským krajem. Odtud pokračuje do Ústeckého kraje, kde se vlévá do Labe. Již v historii poskytovala Ohře vláhu pro zemědělství, významný byl i rybolov, či doprava produktů. Nyní je zdrojem vody pro průmysl, zemědělství i potřeby běžných občanů. Co se týká biologické hodnoty, vlnící se Ohře obsahuje značné množství slepých ramen a tůní, které podporují biodiverzitu. Najdeme zde ovšem i úsek, který je stále napřímený a tím je Černý mlýn-Sokolov (Karlovarský kraj, ©2024).



Graf 2 Zastoupení krajinného pokryvu Karlovarského kraje pro rok 2018. Tento graf byl vytvořen na základě dat ČSÚ.

## 5.2 Ústecký kraj

Ústecký kraj se nachází na severozápadní části ČR. S Karlovarským krajem sousedí na jihozápadě. Ústecko lze rozdělit na čtyři charakteristicky odlišné regiony. První je oblast mostecké pánve zahrnující Chomutov, Most, Teplice a Ústí nad Labem. Tento region je charakteristický svou hornickou činností a značným zastoupením průmyslu. Druhý region zahrnuje oblast Loun a Litoměřic. Jedná se převážně o zemědělskou oblast s menším zastoupením průmyslu a nalezneme zde více menších sídel, než velkých měst (businessinfo, ©2024).

### 5.2.1 Lesy

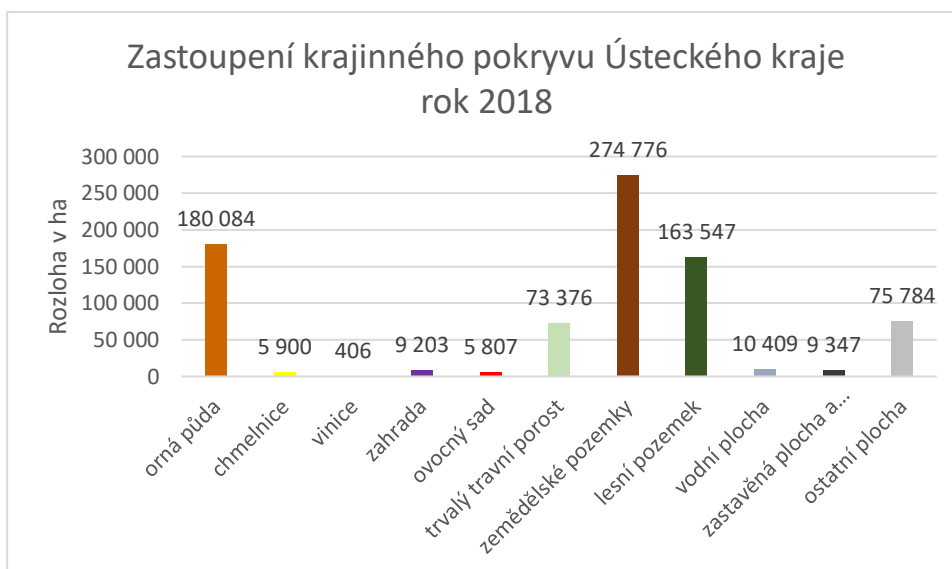
Zajímavostí Ústeckého kraje je, že je jedním z nejméně lesnatých krajů v rámci ČR. Tato skutečnost je způsobena intenzivní těžbou uhlí. Nadpoloviční většinu zde tvoří jehličnany (Ústecký kraj 2024). Mezi lety 2017 až 2020 se zvýšila těžba dřeva až na trojnásobek. Bylo to způsobeno především likvidací kalamit (ČSÚ, ©2021).

### 5.2.2 Zemědělství

Ústecký kraj se vyznačuje značným zastoupením zemědělské půdy (viz. Graf 3). V oblastech Polabí a Poohří se nachází velmi úrodné půdy. Pro tento kraj je charakteristické pěstování chmele v okolí Žatecka a dále produkce obilnin či řepky. Dominantní způsob obhospodařování půdy je zde intenzivní zemědělství (Ústecký kraj, ©2024).

### 5.2.3 Vodstvo

Území Ústeckého kraje je tvořeno sítí řek. Mezi největší patří Labe se svým levostranným přítokem Ohří a pravostranným přítokem Ploučnicí. Kvůli intenzivní důlní činnosti bylo vytvořeno umělé koryto pro řeku Bílinu. Z hlediska vodních nádrží je nejvýznamnější nádrž Nechanice, jenž je šestou největší na území ČR. (Regiony České republiky, ©2024)

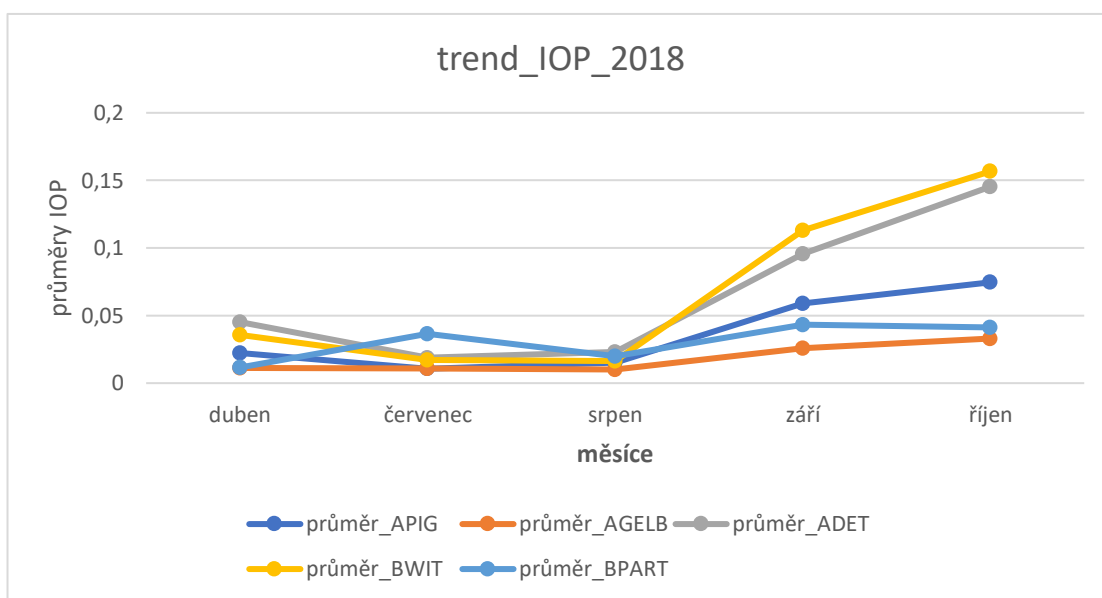


Graf 3 Zastoupení krajinného pokryvu Ústeckého kraje pro rok 2018. Tento graf byl vytvořen na základě dat ČSÚ.

## 6 Výsledky

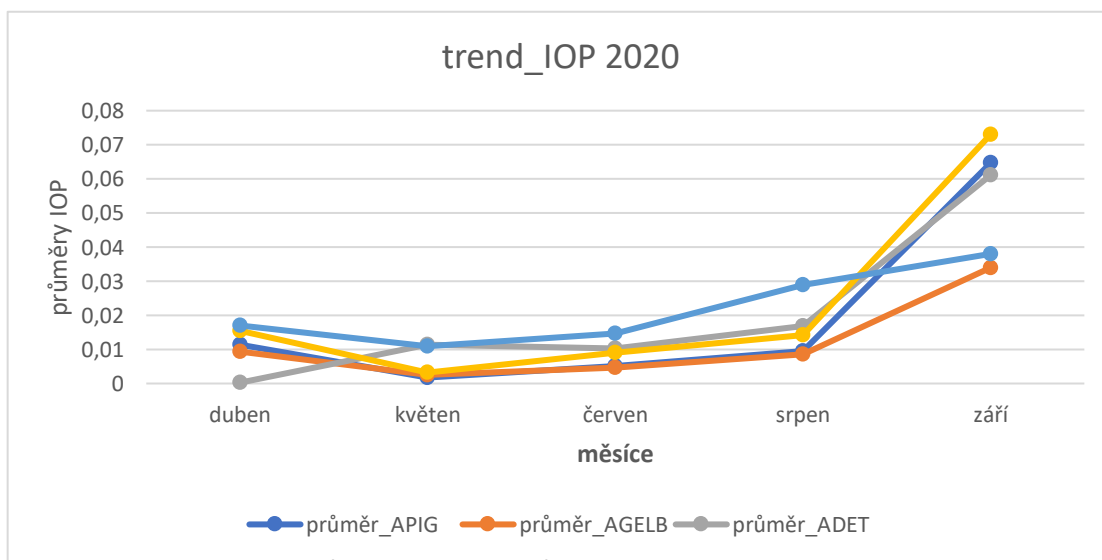
Analyzované byly roky 2018 a 2020 ve vegetačním období od dubna do října na základě snímku družice Sentinel-2. S ohledem na množství oblačnosti nebylo možné uspokojit potřebu zastoupení alespoň jednoho snímku pro každý měsíc. V roce 2020 byly zpracovány měsíce duben, květen, červen, srpen a září. V roce 2018 měsíce duben, červenec, srpen, září a říjen.

### 6.1 Trendy IOP



Graf 4 Vizualizace trendů IOPs pro rok 2018, zdroj: vlastní

V první řadě byl zkoumán trend jednotlivých IOP (graf 4 a 5). První polovina roku z obou let se jeví jako poměrně stabilní, kromě výkyvu BWIT v červenci roku 2018. Největší nárůst všech hodnot byl zaznamenán od srpna do září, kdy některé hodnoty vzrostly až o hodnotu 0,1. Největší nárůst se objevil u BWIT a ADET, naopak nejmenší nárůst zaznamenal AGELB. Tento trend se potvrdil jak v roce 2018, tak 2020. Z hlediska celkového znečištění lze konstatovat, že rok 2018 již v září dosahuje o čtvrtinu vyšších hodnot IOP, než rok 2020.



Graf 5 Vizualizace trendů IOPs pro rok 2020, zdroj: vlastní

rok 2018	<i>průměr_APIG</i>	<i>průměr_AGELB</i>	<i>průměr_ADET</i>	<i>průměr_BWIT</i>	<i>průměr_BPART</i>
<b>průměr_APIG</b>	1				
<b>průměr_AGELB</b>	0,990210257	1			
<b>průměr_ADET</b>	0,988433431	0,982393106	1		
<b>průměr_BWIT</b>	0,996812572	0,99571521	0,993464982	1	
<b>průměr_BPART</b>	0,646528056	0,728833634	0,595479694	0,669325659	1

Tabulka 2 Korelační matice jednotlivých IOPs pro rok 2018, zdroj: vlastní

rok 2020	<i>průměr_APIG</i>	<i>průměr_AGELB</i>	<i>průměr_ADET</i>	<i>průměr_BWIT</i>	<i>průměr_BPART</i>
<b>průměr_APIG</b>	1				
<b>průměr_AGELB</b>	0,996837597	1			
<b>průměr_ADET</b>	0,944689842	0,927717283	1		
<b>průměr_BWIT</b>	0,999367399	0,998249329	0,941387415	1	
<b>průměr_BPART</b>	0,849624666	0,875316392	0,845324436	0,862473733	1

Tabulka 3 Korelační matice jednotlivých IOPs pro rok 2020, zdroj: vlastní

Korelační matice (tab. 2 a 3) ukázaly, že v obou letech existuje ve všech IOP značná korelace. Jedinou středně silnou korelaci prokázal BPART v roce 2018, ovšem v roce 2020 se zdá být silnější a stabilnější.

## 6.2 Zhodnocení IOP v závislosti na NDVI a BSI

Jelikož největší hodnoty IOP byly zaznamenány v září 2020 a říjnu 2018, byly tyto měsíce vybrány jako nejvhodnější pro účely zhodnocení co největšího vlivu krajiny na kvalitu vody.

### 6.2.1 NDVI

Z výsledků korelací jednotlivých IOP na NDVI (tab. 4 a 5) vychází slabá až středně silná záporná korelace. Čím jsou hodnoty NDVI vyšší, tím hodnoty IOP jsou menší. Jelikož vysoké hodnoty NDVI charakterizují vyšší vegetaci, lze usuzovat, že stromy v blízkosti řek dokáží zachytit část polutantů, které by se jinak dostaly do řeky.

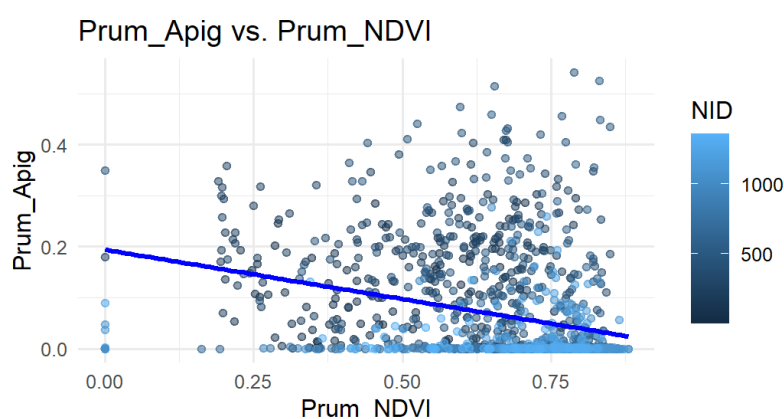
korelace: NDVI_2018	
Prum_Agelb vs. Prum_NDVI	-0.2955
Prum_Adet vs. Prum_NDVI	-0.3887
Prum_Apig vs. Prum_NDVI	-0.2957
Prum_Bwit vs. Prum_NDVI	-0.3702
Prum_Bpart vs. Prum_NDVI	-0.3108

Tabulka 4 Korelace jednotlivých IOPs pro rok 2018 s indexem NDVI, zdroj: vlastní


Zajímavý poznatek přineslo zhodnocení Apig na NDVI v kontextu s hodnotou NID, které vidíme na grafu č. 6. NID charakterizuje identifikační číslo každého úseku řeky. Hodnoty pod 400 (tmavě modré) se nachází od Žatce po obec Rokle. V grafu se tyto tmavé hodnoty nachází spíše ve vyšších hodnotách Apig. V kontextu se satelitními snímky (obr. 6) je vidět zcela rozdílné pokrytí krajiny. S vyšším číslem NID nacházíme spíše trvalé travní porosty, přičemž v nízkých NID vidíme sklizené pole.

korelace: NDVI_2020	
Prum_Adet vs. Prum_NDVI	-0.4052153
Prum_Apig vs. Prum_NDVI	-0.3953830
Prum_Bwit vs. Prum_NDVI	-0.4085133
Prum_Bpart vs. Prum_NDVI	-0.3227955

Tabulka 5 Korelace jednotlivých IOPs pro rok 2020 s indexem NDVI, zdroj: vlastní



Graf 6 Znárodnění závislosti Apig na indexu NDVI pro rok 2020, zdroj: vlastní



Obrázek 6 Vizualizace zón s NID pod 400, které jsou nejvíce znečištěné v kontextu se snímek Sentinel-2 v září 2020, zdroj vlastní

## 6.2.2 BSI

Korelaci IOP s indexem BSI ukazují tabulky č. (6 a 7) a znázorňují opět slabší hodnoty v roce 2018 a středně silné v roce 2020. Korelace je pozitivní, tudíž čím více rostou hodnoty IOP, tím více roste i hodnota indexu. Očekávalo se, že hodnoty tohoto indexu vysvětlí lépe souvislosti s kvalitou studovaných povrchových vod. Jelikož větší znečištění se ukazuje skutečně tam, kde dle satelitních snímků se nachází městské oblasti či sklizená pole, zvolená obalová zóna pro extrakci BSI byla nedostatečně velká.

Korelace: BSI_2018	
Prum_Adet vs. bsi_L_MEAN	0.3573
Prum_Apig vs. bsi_L_MEAN	0.2626
Prum_Bwit vs. bsi_L_MEAN	0.3370
Prum_Bpart vs. bsi_L_MEAN	0.2631
Prum_Agelb vs. bsi_L_MEAN	0.2571

Tabulka 6 Korelace jednotlivých IOPs pro rok 2018 s indexem BSI, zdroj: vlastní

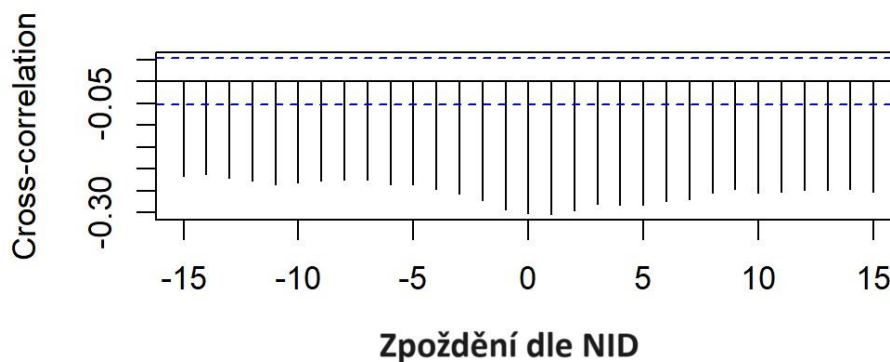
korelace: BSI_2020	
Prum_Adet vs. bsi_L_MEAN	0.4329
Prum_Apig vs. bsi_L_MEAN	0.4168
Prum_Bwit vs. bsi_L_MEAN	0.4423
Prum_Bpart vs. bsi_L_MEAN	0.3567

Tabulka 7 Korelace jednotlivých IOPs pro rok 2020 s indexem BSI, zdroj: vlastní

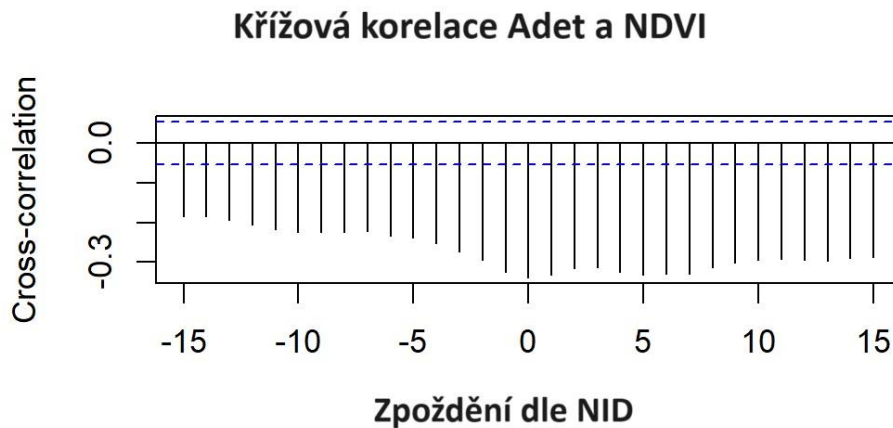
## 6.3 Kros-korelace

Díky kros-korelaci byla zjištěna vzdálenost a průběh projevení každého zkoumaného parametru kvality vody.

### Křížová korelace Apig a NDVI



Graf 7 Křížová korelace mezi Apig a NDVI. zdroj: vlastní



Graf 8 Křížová korelace mezi Apig a NDVI. zdroj: vlastní

Grafy č. (7 a 8) znázorňují průběh a projev znečištění v závislosti na následujících úsecích řeky. Pigmenty fytoplanktonu se projevují stále ve značné míře prvních 100 metrů od zdroje znečištění. Po 250 metrech pozorujeme stále menší závislost. U IOP Adet, který charakterizuje bahno a suspendované sedimenty se primární závislost projevuje u zdroje znečištění, poté 150 metrů lehce klesá a druhého maxima nabírá při 300 metrech. Dále má závislost tendenci klesat.

## 7 Diskuse

Výsledky této práce prokázaly pouze částečně předpokládané chování spektrálních indexů a optických vlastností vody, coby metrik kvality vody.

Stěžejní úloha pro lepší vysvětlení chování spektrálních indexů je zvolení větší oblasti pro extrakci hodnot krajinného pokryvu. Výsledky úzce korespondují s Uriarte (2011), která taktéž neměla uspokojivější výsledky s její obalovou zónou 60 metrů. Vhodnější vzdálenost od řeky, jak Wang (2023) tvrdí, by se mohla pohybovat až 1000 metrů. Pro rozšíření plochy zóny krajinného pokryvu by bylo také příhodnější zvětšit i vzdálenosti po řece nebo na základě svažitosti definovat hlavní místa toku látek z okolního prostředí.

Zvolené spektrální indexy dokázaly určit vždy jeden či dva stěžejní typy krajinného pokryvu, ale ukazuje se, že jeden typ znečištění je závislý na několika typech krajinného pokryvu, a proto by bylo vhodnější použít kombinaci hned několika spektrálních indexů. Ačkoli index BSI, který měl detekovat primárně pole postižené erozí a zástavbu nevykazuje větší závislost, při pohledu na satelitní snímky je vidět, že více znečištěné vody jsou skutečně tam, kde se nachází větší množství polí. Závislost kvality vody na zemědělské činnosti potvrzuje také Pratt et Chang (2012)

K vysvětlení těchto vztahů by mohla být použita RDA analýza, která je schopna pracovat s více proměnnými krajinného pokryvu najednou. Její využití přineslo komplexnější pochopení vztahu již Zhang et al. (2022) a v souvislosti s vlivem sezónních změn přinesla pozitivní výsledky i Xu (2021)



## 8 Závěr a přínos práce

Cílem bakalářské práce bylo vyhodnotit vliv krajiny a její změnu na kvalitu řeky Ohře pomocí metod DPZ. Tento úkol byl splněn za použití spektrálních indexů NDVI a BSI k vyhodnocení spektrálních vlastností krajiny. Optické vlastnosti vody byly získány za použití C2RCC procesoru. Byly vytvořeny zóny řeky a jejího okolí pro následnou statistiku. Zonální statistikou proběhla extrakce spektrálních indexů a IOP, které byly následně mezi sebou korelovány pro zjištění vzájemného vztahu.

S ohledem na zvolenou velikost obalové zóny se nejvíce signifikantním vztahem projevila reakce husté vegetace pomocí indexu NDVI, která má pozitivní vliv na veškeré vyhodnocené metriky kvality vody. Naopak s úbytkem vegetace bylo zaznamenáno větší znečištění. Bare Soil Index také prokázal předpokládaný vztah na kvalitu vody, ale nemohl zcela dobře reagovat na zastavěné plochy, jelikož se zpravidla nacházely dále, než byla zvolená vzdálenost obalové zóny od řeky. Proto spíše častěji reagoval na cesty, případně okraje polí. Při vyhodnocení křížovou korelací bylo zjištěno možné zpoždění a průběh projevu znečištění na řece od zdroje znečišťujících látek. V rámci analýzy byl zjištěn průběh zkoumaných metrik znečištění pro vybrané měsíce za dané kalendářní roky. Od dubna po srpen se zpravidla hodnoty IOP příliš neměnily. Od srpna do září byl zaznamenán prudký nárůst všech hodnot IOP pravděpodobně v důsledku zemědělské činnosti.

Bakalářská práce prokazuje, že při vhodném zvolení velikosti zájmových zón lze použít metody DPZ, jakožto spektrální indexy a C2RCC k pravidelnému sledování vztahů mezi typem krajiny, hospodaření v krajině a kvalitou povrchových vod. V budoucím výzkumu by bylo vhodné se zaměřit na navržení metodiky pro tvorbu obalových zón kolem vodních toků s ohledem na nadmořskou výšku a svažítost. Tyto obalové zóny by měly splňovat tvarem a velikostí požadavky k extrakci hodnot spektrálních indexů, případně jejich kombinaci.

## 9 Přehled literatury a použitých zdrojů

Arias-Rodriguez, L. F., Duan, Z., Díaz-Torres, J. D. J., Basilio Hazas, M., Huang, J., Kumar, B. U., ... et Disse, M. (2021). Integration of remote sensing and Mexican water quality monitoring system using an extreme learning machine. *Sensors*, 21(12), 4118.

Brockmann, C., Doerffer, R., Peters, M., Kerstin, S., Embacher, S., & Ruescas, A. (2016, August). Evolution of the C2RCC neural network for Sentinel 2 and 3 for the retrieval of ocean colour products in normal and extreme optically complex waters. In *Living Planet Symposium* (Vol. 740, p. 54).

Brom, J., Nedbal, V., Císař, P., Urban, J., et Tesařová, B. (2022). Hodnocení přítomnosti sinic, řas a dalších ukazatelů kvality vody pomocí metod dálkového průzkumu Země: Certifikovaná metodika.

businessinfo, ©2024: Charakteristika Ústeckého kraje (online) [cit.2023.03.27], dostupné z <https://www.businessinfo.cz/navody/charakteristika-usteckeho-kraje/>

Carstensen, M. V., Hashemi, F., Hoffmann, C. C., Zak, D., Audet, J., et Kronvang, B. (2020). Efficiency of mitigation measures targeting nutrient losses from agricultural drainage systems: A review. *Ambio*, 49, 1820-1837.

Clarke, G., et Ewing, G. (1974). Remote sensing of ocean colour and index of biological and sedimentary activity. *Earth Survey Problems: Akademik-Verlag*, 107-120.

Copernicus, ©2024: Resolution and Swath (online) [cit.2023.03.27], dostupné

ČSÚ, ©2021: Charakteristika Karlovarského kraje (online) [cit.2023.03.27], dostupné

Davies-Colley, R. J. (1992). Yellow substance in coastal and marine waters round the South Island, New Zealand. *New Zealand journal of marine and freshwater research*, 26(3-4), 311-322.

Dube, T., Gumindoga, W. et Chawira, M. (2014) Detection of land cover changes around Lake Mutirikwi, Zimbabwe, based on traditional remote sensing image classification techniques. *African Journal of Aquatic Science* 39(1), 89–95. h

Feng, L., Hou, X., Li, J., et Zheng, Y. (2018). Exploring the potential of Rayleigh-corrected reflectance in coastal and inland water applications: A simple aerosol correction method and its merits. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 52-64.

Garg, V., Kumar, A. S., Aggarwal, S. P., Kumar, V., Dhote, P. R., Thakur, P. K., ... et Rastogi, G. (2017). Spectral similarity approach for mapping turbidity of an inland waterbody. *Journal of hydrology*, 550, 527-537.

- Gholizadeh, M. H., Melesse, A. M., et Reddi, L. (2016). A comprehensive review on water quality parameters estimation using remote sensing techniques. *Sensors*, 16(8), 1298.
- Gordon, H. R., et Clark, D. K. (1981). Clear water radiances for atmospheric correction of coastal zone color scanner imagery. *Applied optics*, 20(24), 4175-4180.
- Goyenola, G., Graeber, D., Meerhoff, M., Jeppesen, E., Teixeira-de Mello, F., Vidal, N., ... et Kronvang, B. (2020). Influence of farming intensity and climate on lowland stream nitrogen. *Water*, 12(4), 1021.
- Horák, J. (2014). Dálkový průzkum Země. Ostrava: VŠB-TU Ostrava.
- Hovis, W. A., Clark, D. K., Anderson, F., Austin, R. W., Wilson, W. H., Baker, E. T., ... & Yentsch, C. S. (1980). Nimbus-7 Coastal Zone Color Scanner: system description and initial imagery. *Science*, 210(4465), 60-63.
- Jiang, D., Matsushita, B., Pahlevan, N., Gurlin, D., Fichot, C. G., Harringmeyer, J., ... et Spyarakos, E. (2023). Estimating the concentration of total suspended solids in inland and coastal waters from Sentinel-2 MSI: A semi-analytical approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 204, 362-377.
- Kimes, D. S., Nelson, R. F., Salas, W. A., et Skole, D. L. (1999). Mapping secondary tropical forest and forest age from SPOT HRV data. *International Journal of Remote Sensing*, 20(18), 3625-3640.
- Kvítek, T. (2015). Povodně, sucho, eroze, jakost povrchové a pozemní vody, hladiny podzemních vod a společný ukazatel–malá retence vody v krajině PÚ 4/2015.
- Llodrà-Llabrés, J., Martínez-López, J., Postma, T., Pérez-Martínez, C., et Alcaraz-Segura, D. (2023). Retrieving water chlorophyll-a concentration in inland waters from Sentinel-2 imagery: Review of operability, performance and ways forward. *International Journal of Applied Earth Observation and Geoinformation*, 125, 103605.
- Majer, D., 2021: Třetí člen řady Sentinel 2 (online) [cit.2023.03.27], dostupné z <https://kosmonautix.cz/2021/08/treti-clen-rady-sentinel-2/>
- Mobley, C. D., Stramski, D., Paul Bissett, W., et Boss, E. (2004). Optical modeling of ocean waters: Is the case 1-case 2 classification still useful?. *Oceanography*, 17(SPL. ISS. 2), 60.
- Morel, A., et L. Prieur, (1977) Analysis of variations in ocean color. *Limnol. Oceanogr.*, 22(4), 709-722.
- Moses, W. J., Sterckx, S., Montes, M. J., De Keukelaere, L., et Knaeps, E. (2017). Atmospheric correction for inland waters. In *Bio-optical modeling and remote sensing of inland waters* (pp. 69-100). Elsevier.

Mzuza, M. K., Zhang, W., Kapute, F., et Wei, X. (2019). The impact of land use and land cover changes on the Nkula Dam in the Middle Shire River Catchment, Malawi. *Geospatial analyses of earth observation (EO) data*, 9.

Nguyen, C. T., Chidthaisong, A., Kieu Diem, P., et Huo, L. Z. (2021). A modified bare soil index to identify bare land features during agricultural fallow-period in southeast Asia using Landsat 8. *Land*, 10(3), 231.

Peacock, R., et Missouri, M. A. R. Y. V. I. L. L. E. (2014). Accuracy assessment of supervised and unsupervised classification using Landsat imagery of Little Rock, Arkansas. *Master of Science thesis*.

Perrone, M., Scalici, M., Conti, L., Moravec, D., Kropáček, J., Sighicelli, M., ... & Malavasi, M. (2021). Water mixing conditions influence Sentinel-2 monitoring of chlorophyll content in monomictic lakes. *Remote Sensing*, 13(14), 2699.

Pires de Lima, R., & Marfurt, K. (2019). Convolutional neural network for remote-sensing scene classification: Transfer learning analysis. *Remote Sensing*, 12(1), 86.

POH, ©2018: Výroční zpráva 2018 (online) [cit.2023.03.27], dostupné z [https://www.poh.cz/assets/File.ashx?id\\_org=200341&id\\_dokumenty=3637](https://www.poh.cz/assets/File.ashx?id_org=200341&id_dokumenty=3637)

POH, ©2020: Výroční zpráva 2020 (online) [cit.2023.03.27], dostupné z [https://www.poh.cz/assets/File.ashx?id\\_org=200341&id\\_dokumenty=7279](https://www.poh.cz/assets/File.ashx?id_org=200341&id_dokumenty=7279)

Pratt, B., et Chang, H. (2012). Effects of land cover, topography, and built structure on seasonal water quality at multiple spatial scales. *Journal of hazardous materials*, 209, 48-58.

Ramadas, M., et Samantaray, A. K., (2018) Applications of remote sensing and gis in water quality monitoring and remediation: a state-of-the-art review. In: *Water Remediation* (Bhattacharya, S., Gupta, A. B., Gupta, A. & Pandey, A., eds). Springer Singapore, Singapore, pp. 225–246.

Regiony České republiky, ©2024: Vodstvo (online) [cit.2023.03.27], dostupné z <https://regiony.lusa.cz/ustecky-kraj/vodstvo/>

Regiony České republiky, ©2024: Vodstvo (online) [cit.2023.03.27], dostupné z <https://regiony.lusa.cz/ustecky-kraj/vodstvo/>

Sent, G., Biguino, B., Favareto, L., Cruz, J., Sa, C., Dogliotti, A. I., ... et Brito, A. C. (2021). Deriving water quality parameters using sentinel-2 imagery: A case study in the Sado Estuary, Portugal. *Remote sensing*, 13(5), 1043.

Schiller, H., et Doerffer, R. (1999). Neural network for emulation of an inverse model operational derivation of Case II water properties from MERIS data. *International journal of remote sensing*, 20(9), 1735-1746.

Song, Y., Song, X., Shao, G., et Hu, T. (2020). Effects of land use on stream water quality in the rapidly urbanized areas: A multiscale analysis. *Water*, 12(4), 1123.

Ta, P., Tetzlaff, B., Trepel, M., & Wendland, F. (2020). Implementing a Statewide Deficit Analysis for Inland Surface Waters According to the Water Framework Directive—An Exemplary Application on Phosphorus Pollution in Schleswig-Holstein (Northern Germany). *Water*, 12(5), 1365.

Tůma, J., et Kacálková, L. (2004). Změny vybraných ukazatelů kvality povrchových vod v oblasti Králicka. *Vč. Sb. Přír.-Práce a studie*, 11: 13, 23.

Uriarte, M., Yackulic, C. B., Lim, Y., et Arce-Nazario, J. A. (2011). Influence of land use on water quality in a tropical landscape: a multi-scale analysis. *Landscape ecology*, 26, 1151-1164.

Ústecký kraj, ©2024: Zemědělství (online) [cit.2023.03.27], dostupné z <https://www.kr-ustecky.cz/zemedelstvi/ds-99371>

Vinciková, H. (2015) Krajinné struktury, využití území a kvalita povrchových vod: Studium vzájemných vztahů nástroji DPZ. Č. Budějovice. disertační práce (Ph.D.). JIHOČESKÁ UNIVERZITA V ČESKÝCH BUDEJOVICÍCH. Zemědělská fakulta.

Vitousek, P. M., Naylor, R., Crews, T., David, M. B., Drinkwater, L. E., Holland, E., Johnes, P. J., Katzenberger, J., Martinelli, L. A., Matson, P. A., Nziguheba, G., Ojima, D., Palm, C. A., Robertson, G. P., Sanchez, P. A., Townsend, A. R. et Zhang, F. S. (2009) Nutrient imbalances in agricultural development. *Science* 324(5934), 1519.

Wang, W., Yang, P., Xia, J., Huang, H., et Li, J. (2023). Impact of land use on water quality in buffer zones at different scales in the Poyang Lake, middle reaches of the Yangtze River basin. *Science of The Total Environment*, 896, 165161.

Weier, J., & Herring, D. (2000). Measuring vegetation (ndvi & evi). *NASA Earth Observatory*, 20(2).

Wentzel, K. (2002). Determination of the overall soil erosion potential in the Nsikazi District (Mpumalanga Province, South Africa) using remote sensing and GIS. *Canadian journal of remote sensing*, 28(2), 322-327.

Xu, J., Liu, R., Ni, M., Zhang, J., Ji, Q., et Xiao, Z. (2021). Seasonal variations of water quality response to land use metrics at multi-spatial scales in the Yangtze River basin. *Environmental Science and Pollution Research*, 28, 37172-37181.

z [https://www.czso.cz/csu/xk/charakteristika\\_karlovarskeho\\_kraje](https://www.czso.cz/csu/xk/charakteristika_karlovarskeho_kraje)

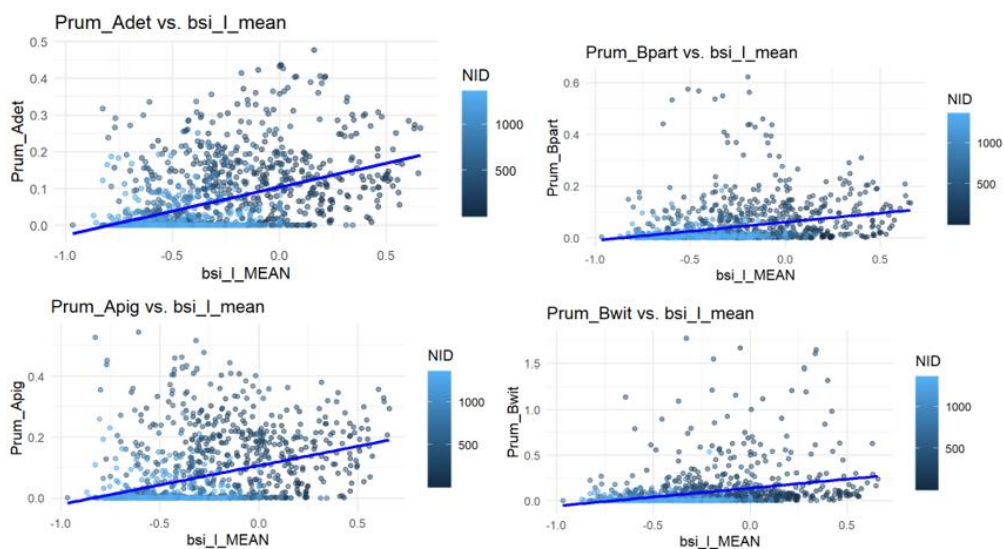
Z <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2/instrument-payload/resolution-and-swathe>

Zhang, F., Chen, Y., Wang, W., Jim, C. Y., Zhang, Z., Tan, M. L., ... & Rahman, H. A. (2022). Impact of land-use/land-cover and landscape pattern on seasonal in-stream water quality in small watersheds. *Journal of Cleaner Production*, 357, 131907.

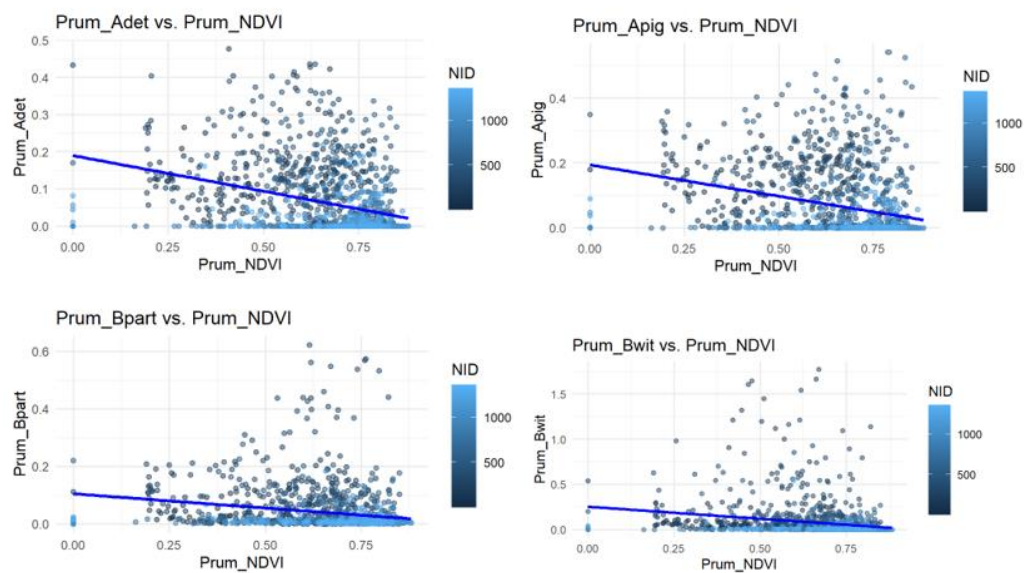
Žubrietovský et al., 2017: (online) [cit.2023.03.27], dostupné z <https://collgs.czechspaceportal.cz/wp-content/uploads/2020/08/sentinel2czfinal.pdf>

## 10 Přílohy

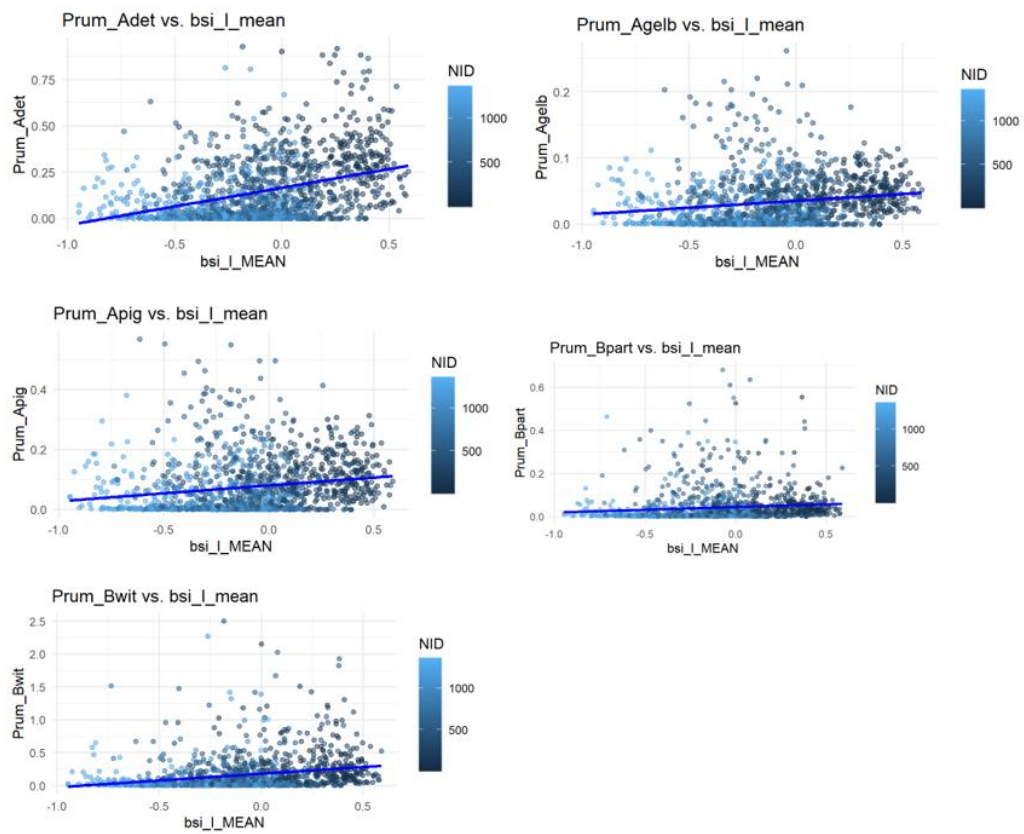
Příloha 1 Scatter plot závislosti IOPs na BSI, rok 2020



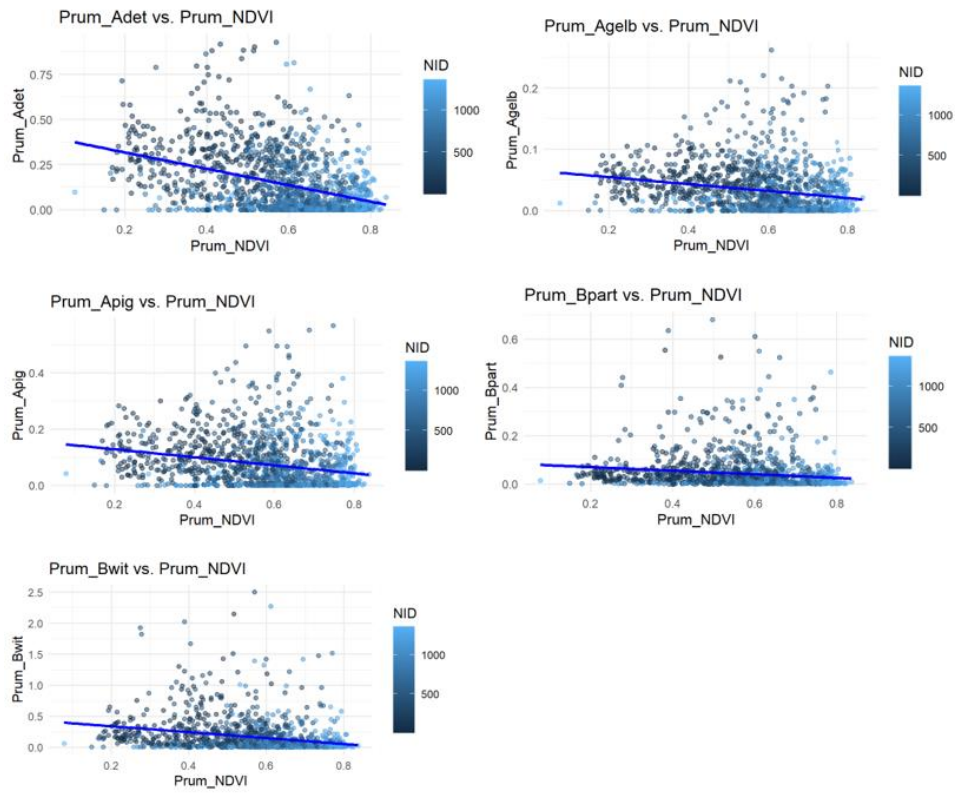
Příloha 2 Scatter plot závislosti IOPs na NDVI, rok 2020



Příloha 3 Scatter plot závislosti IOPs na BSI pro rok 2018



Příloha 4 Scatter plot závislosti IOPs na NDVI pro rok 2018



Příloha 5 Křížové korelace IOPs a BSI pro rok 2020

